# 面向用户长短期偏好调节的可解释个性化推荐方法研究*

李伟卿[1,2] 池毛毛[1] 王伟军[2]
[1] 华中师范大学信息管理学院 武汉 430079
[2] 华中师范大学青少年网络心理与行为教育部重点实验室 武汉 430079

摘 要：[目的/意义]针对目前推荐模型愈加复杂、数据输入越来越多、传统推荐模型可解释性较低、推荐结果"过度特化"等问题，提出面向用户长短偏好调节的可解释个性化推荐方法。[方法/过程]从用户近期产品需求及其长期生活方式两个维度构建用户长短偏好模型，借鉴用户评分偏置及注意力机制，将用户长短偏好与其评分相结合进行评分预测，从而形成Top-N推荐。[结果/结论]通过在两个数据集上的实验结果表明，本方法对于不同的用户行为(显式反馈或隐式反馈)，不同的推荐项目个数及在不同的推荐算法中都有良好表现。在无需对各种推荐模型进行较大改变的情况下，提升了推荐结果的准确率、召回率与多样性；另外基于对长短偏好系数的改变，实现对推荐结果多样性与准确率的调整，并且形成相应的推荐解释。

关键词：个性化推荐 用户偏好 可解释性 长短偏好调节
分类号：G203
DOI：10.13266/j.issn.0252-3116.2021.12.010



## 1 引言

个性化推荐一直是学界和业界的研究热点。个性化推荐系统的成功与否在很大程度上取决于其识别与表示用户偏好的能力，如何全面并深层次理解用户的行为和偏好，如何将用户行为和产品特征数据有效地融入推荐模型，是提升推荐系统性能的关键[1]。很多学者已经进行了大量的探索与研究。

例如H. Naji[2]首先对用户的心理特征和人口统计学信息进行贝叶斯分类，然后结合协同过滤推荐算法形成推荐，在Movielens数据集上取得了不错的效果；X. Zhao等[3]将微博用户的人口统计学信息及从产品评论中提取出的产品特征融入相似度排序算法中形成推荐；Y. Huang等[4]从用户生活方式和情感维度来丰富用户的偏好属性，基于用户网络评论文本构建了一个七维度的用户在线生活方式词典，并将其纳入经典的协同过滤推荐系统中，提升了用户偏好的预测性能；侯银秀等[5]考虑到用户偏好中的情感特征，使用情感分析方法对用户图书评论信息进行图书属性的情感挖掘，提出了基于用户情感偏好与产品属性情感匹配的图书个性化推荐方法。近年来深度学习由于其优异的特征提取与表示能力，在推荐领域也取得了广泛的关注与研究。J. Bi等[6]使用用户平均评分、用户基本数据(用户性别、用户年龄、用户职业、用户ID)、项目基本数据(项目名称、项目类别、项目ID)和项目平均评分，建立一个基于深度神经网络的用户评价预测模型，并基于此产生推荐，实验结果表明，该算法不仅优于目前最先进的协同过滤推荐算法，而且能有效地解决数据稀疏和冷启动问题；梁昌勇等[7]提出一种基于卷积神经网络与隐语义模型的推荐模型(CNN-LFM)，该模型利用隐语义模型挖掘评分数据，获得用户和物品的潜在特征，使用卷积神经网络提取图像视觉内容来学习物品的潜在特征，将CNN与LFM有效结合，充分利用物品内容信息和用户物品交互信息，提升了用户偏好的预测效果。

综上所述，现有的个性化推荐研究在特征的提取与表征、用户偏好的精准识别、推荐预测的准确度以及对数据稀疏性和冷启动问题的改善等方面，取得了较

* 本文系国家自然科学基金项目"面向青少年网络适应的个性化信息服务优化方法研究"(项目编号：71974072)和国家自然科学基金项目"基于屏幕视觉热区的网络用户偏好提取及交互式个性化推荐研究"(项目编号：71571084)研究成果之一。
作者简介：李伟卿(ORCID：0000-0002-4108-2829)，博士研究生；池毛毛(ORCID：0000-0003-2726-5933)，副教授，博士；王伟军(ORCID：0000-0002-6077-1101)，教授，博士，博士生导师，通讯作者，E-mail：wangwj@ccnu.edu.cn。
收稿日期：2020-12-09 修回日期：2021-02-24 本文起止页码：101-111 本文责任编辑：杜杏叶

好的研究进展,但也造成了以下几点问题:①为了提升推荐性能,新提出的推荐模型变得愈加复杂和冗余,提升了算法复杂度,另外模型的频繁改动可能不利于研究成果在实际生产中应用与迭代;②深度学习的“黑箱子”特性,导致推荐结果的可解释性不足,用户不清楚推荐的依据是什么,可能降低用户对推荐系统的满意度和信任度;③推荐结果“过度特化”问题,过于追求推荐结果的准确率,可能导致推荐结果偏于单一及重复推荐,降低用户的满意度。

因而,本文提出一种面向用户长短偏好调节的可解释个性化推荐方法,根据用户近期关注的产品类别及其长期生活方式构建长短偏好模型,借鉴用户评分偏置及注意力机制,通过调整用户各方面偏好的权重,生成不同的推荐列表,并形成相应解释。具体而言,首先,基于用户的显式反馈和隐式反馈,得到用户对于单一产品的直接评分;然后根据用户的近期需求和长期生活方式及其行为时间周期构建用户长短偏好模型;将以上用户偏好信息纳入推荐系统构建 User-Item 偏好矩阵,调整偏好权重系数以实现面向用户长短偏好调节的可解释性推荐模型。本文提出的方法创新性主要体现在:①基于生活方式理论对产品特征进行划分,从用户近期需求和长期生活方式两个维度构建用户长短偏好模型,可更全面细致预测用户偏好,提升推荐准确性;②从用户近期的产品需求和用户长期生活方式两个方面提升了推荐结果的可解释性;③探讨了个性化推荐系统评价指标的可调节机制,基于用户长短偏好系数的改变,对推荐结果的准确率和多样性进行调整,为应对推荐结果的“过度特化”问题提供思路。



## 2　相关研究

关于用户长短偏好的识别及可解释个性化推荐,国内外学者已进行了多方面研究,下面将对两个方面的相关成果进行介绍。

### 2.1　用户长短偏好识别

如何全面并深层次理解用户的兴趣与偏好,是推荐系统成功的关键。偏好通常指的是个人对客观事物的选择态度,表现为一个人认识、探索、接近或者获取某种客观事物的意向,是个性最明显的表现[1]。个人偏好可以通过其行为表现出来,因此通过用户的浏览、点击、购买、评论等行为,可以推断出用户在某一段时间内的偏好与关注信息[8]。用户偏好存在其稳定的一面,同时也随着时间、用户的年龄、经历等不断变化。因此,用户偏好包括长期偏好和短期偏好两个主要部分。短期偏好体现了用户近期的关注与兴趣变化,长期偏好体现了用户持续性的特质与心理因素,相对比较稳定,二者结合能够更加准确地刻画用户完整的偏好信息[9]。用户的网络行为、购买决策及偏好受到很多因素影响,如情绪、功能、情境等,呈现复杂、多样、多变的特点。用户行为是外显的,不能完全代表其内在、本质的心理特征,且外在行为变化快,具有不稳定性。

因此,如何从用户外在行为中提取出用户内在的、稳定的购买行为影响因素,将其作为推荐依据,是本研究的关键。用户购买行为是文化、社会等外部因素以及生活方式、价值观等个人因素决定[10]。生活方式是人们根据某一中心目标安排其生活模式,并通过其语言、行为和兴趣等表现出来。生活方式也被理解为“一个人花费时间和金钱的方式”。用户的生活方式是其需求、价值观及经历所形成的意见、态度的外在表现,会显著影响用户的购买行为。生活方式是个体买什么和不买什么,做什么和不做什么,什么能吸引个体和什么不能吸引个体所形成的一贯模式[11]。I. Sarki 等[12]发现,个体的价值观和生活方式与其品牌偏好显著相关,W. Swinyard[13]研究发现个体的生活方式与其购买频率、花费的金钱成本和时间成本有显著的相关性。潘煜等[14]提出用户的生活方式对于产品的功能价值、感知成本和形象价值有显著的影响,产品的价格影响用户的感知成本,产品品牌与形象价值显著相关。罗莉娟等[15]发现网络生活方式对个人用户的功能感知、品牌感知、服务感知及购买行为均有直接影响。以上研究表明生活方式会显著地影响用户对于产品的价格、品牌、功能等因素的选择,从而影响用户的购买行为,然而因为用户内在特征的抽象性和难以识别,现有推荐系统较少地考虑如何根据用户的生活方式特征进行推荐。

推荐模型中如何识别与表示用户的长短偏好,现有研究也已进行了大量探索:如 L. Xiong 等[16]提出利用衰减函数 $f(x)=e^{-\alpha t}$ 来量化用户过去评分对用户偏好的影响,其中 t 是给出评分的时间,α 是控制时间的衰减率;王伟军等[17-18]研究发现用户浏览时存在屏幕视觉热区,并据此实时提取热区中短文本信息作为用户即时关注偏好的参考依据;然后结合用户的即时偏好、长短偏好及情境因子形成用户偏好整合模型,实现交互收敛式个性化推荐方法;L. Hu 等[19]提出的基于用户长短期兴趣的图神经网络新闻推荐模型,提取用户近期与长期的交互项与新闻内容特征,预测用户长期与短期的信息偏好;D. Chen 等[20]提出的基于长、短

期注意力记忆网络的序列感知模型，对每个周期内的用户会话进行向量化表示（embedding），并使用一个带有注意力机制的记忆神经网络学习长期偏好与短期偏好的权重；L. Xiang 等[21]提出了基于会话的时间图算法以同时对用户长期和短期偏好进行建模，将此偏好模型结合随机游走算法形成基于时间感知的个性化推荐。王薇薇等[22]将用户当前更新周期内的浏览记录所表现的用户兴趣称为短期偏好；用户持续的浏览历史记录所表现的用户兴趣称为长期偏好，并提出一种基于用户行为反馈的兴趣度模型更新算法，分析用户的购买记录和浏览行为，实现用户偏好的即时更新，得到针对用户动态偏好的个性化推荐列表。总的来说，现有的用户长短偏好模型多是从算法层面，针对不同时间周期，对用户的行为如会话、浏览、购买、打分进行权重赋值以调整用户不同时间窗口内的行为信息权重；或者通过深度学习中的长短记忆网络，自动学习提取用户长短期偏好。缺乏从用户内在特质层面深入挖掘用户长短偏好的差别。

### 2.2 可解释个性化推荐

当用户必须在不同的备选方案之间做出决定，或者需要评估推荐结果的质量时，只显示推荐列表而无解释性信息会让用户难以判定推荐项目的有用性[23]。推荐结果的可解释性对于推荐系统的发展与提升至关重要。可解释推荐是一种解释为什么推荐某个项目的方法，近年来，可解释推荐已经成为社交媒体、电子商务和内容共享网站等许多网络应用研究中一个广受关注的课题。适当推荐理由的展示可以提高用户对于推荐结果的接受程度，通过解释系统是如何工作的或为什么一个项目会被推荐，系统会变得更加透明，从而提升用户的信任度，且有可能让用户知道系统何时出错，帮助用户做出更好和更快的决定，提升用户的满意度[24－25]。余以胜等[26]将目前的可解释推荐分为三类：①以贡献最大的因子作为推荐解释，要求每个因子都能对应一个可以作为推荐理由的要素，如用户或者物品的特征及标签；②采用预定义的规则短语，如亚马逊提出的“购买了此产品的用户也购买了……”，或者社交网站中“你的好友也关注了、查看了该内容”等，这种方法较为容易部署，但是理由千篇一律，对提升用户的信任度，促进购买的作用有限；③引入文本评论特征作为推荐理由，如 Y. Zhang 等[27]通过从评论中提取用户对产品各方面的明确意见，了解用户更关心哪些方面的细节，从而提出可解释的建议。另外，深度学习注意力机制，能够帮助算法捕捉数据中需要重点关注的部分[28]，如文献[29－30]提出的可解释深度学习评分预测模型，在预测用户－项目评分时，基于学习得到的注意力权重，该模型可以显示评论中哪个部分对预测结果更重要，突出评论中的重要词汇作为解释，帮助用户理解推荐。

综上，推荐解释根据相应系统所使用的算法和数据得到，其差异体现在生成方式和表现形式上，其主要逻辑是以特定的形式向用户展示推荐结果生成的原因，如用户或产品的相似度，或者用户对于某种产品或者特征的偏好等。基于此，本研究结合网络生活方式的定义及其对用户购买决策的影响因素，将用户的价格和品牌偏好作为其长期生活方式偏好特征，产品类别作为用户的近期需求偏好。借鉴评分偏置的思想[26,31]，将用户的长短期特征偏好融入其直接评分；并结合注意力机制[28－30]，调整特征权重，使推荐结果关注权重更高的用户偏好特征，并形成相应的解释。

## 3 研究方法

### 3.1 基于用户行为的产品直接评分

用户行为包括打分、购买、收藏（加购物车）、点击次数、浏览时间 5 个方面。其中打分是用户的显示反馈，其余皆为用户的隐式反馈。5 个因素的重要性等级为：浏览 < 点击 < 收藏 < 购买 < 显性评分[32]，基于此本研究采用 5 点打分法定义用户以上行为，将用户每一次成功交互的产品直接评分记为 $p_{ui}$。

### 3.2 用户长短偏好模型

当前周期的用户行为所表现的兴趣称为短期偏好。若在周期 T 内，用户购买、收藏、浏览某种特征的产品次数增加，相应的用户对此类特征的偏好程度较高，或者可能对此类特征相关的产品偏好程度较高。则当前周期内用户对某一类特征的短期偏好记为公式（1）：

$$p^{now} = \alpha h_{ui} + \beta p_{ui} \qquad \text{公式(1)}$$

$h_{ui}$表示在当前周期 $T$ 内，用户对此类特征产品的关注频率，记为 $h_{ui} = \frac{tf_{u_i}}{\sum_{j=1}^{n} tf_{u_j}}$；$\alpha$ 和 $\beta$ 是系数，且 $\alpha + \beta = 1$[22]。相应的用户对此特征的长期偏好表示为公式（2）：

$$p^{per} = \frac{1}{n} \sum_{i=1}^{n} e^{-i} \times p_i^{now} \qquad \text{公式(2)}$$

其中，$p_i^{now}$ 表示第 i 个周期形成的用户兴趣，结合用户的短期偏好和长期偏好，将用户长短偏好表示成公式（3）：

$$p = x * p^{now} + y * p^{per} \qquad 公式(3)$$

其中 $x$、$y$ 是系数，且 $x+y=1$[22]。基于此，对产品的类别和品牌进行 one-hot 编码，采用十分位数原理对同类别产品的所有价格进行区间划分之后。将用户对产品特征的长短偏好表示为以下三元组：($p_{ij_G}$, $p_{ij_P}$, $p_{ij_B}$)。

$$p_{ij_G} = x(\frac{n+1-i}{n} p_i^{now}) \qquad 公式(4)$$

$$p_{ij_P} = y_1(\frac{n+1}{2n} p_P^{per}) \qquad 公式(5)$$

$$p_{ij_B} = y_2(\frac{n+1}{2n} p_B^{per}) \qquad 公式(6)$$

$p_{ij}$代表第 $i$ 个周期内的产品 $j$，$p_{ij_G}$代表用户对于产品类别的短期偏好，$p_{ij_P}$代表用户对于产品感知价格的长期偏好，$p_{ij_B}$代表用户对于品牌的长期偏好，$n$ 表示时间周期数量，$x$、$y_1$、$y_2$ 是系数，$x+y_1+y_2=1$。采用熵权法计算用户长期偏好权重 $y_1$，$y_2$[33]。熵权法是一种客观赋权法，基于信息熵的概念确定相应指标权重。信息熵：$E = -\sum_{i=1}^{n} p_i \log p_i$，表示信源中所有可能发生情况的平均不确定性。熵值越大，表示不确定性越高。基于此，将用户长期感知价格偏好及品牌偏好表示为公式(8)、公式(9)：

$$E_{uP} = -\sum_i^n f_u(P_i) \log f_u(P_i) \qquad 公式(8)$$

$$E_{uB} = -\sum^i f_u(B_i) \log f_u(B_i) \qquad 公式(9)$$

其中，$f_u(P_i)$是用户 $u$ 对感知价格为 $P_i$ 的产品产生行为的概率，行为次数越多，则概率越大，因而对于每一位用户的长期偏好权重，熵值 $E_{uP}$、$E_{uB}$越小，表示用户相应偏好越集中，需要给予其更高的权重。因而：

$$y_1 = (1-x) * \frac{E_{uB}}{E_{uP}+E_{uB}} \qquad 公式(10)$$

$$y_2 = (1-x) * \frac{E_{uP}}{E_{uP}+E_{uB}} \qquad 公式(11)$$

### 3.3 评分偏置

推荐模型通过捕捉用户与项目之间的交互作用进行评分预测，然而评分除了和用户对项目的直接打分有关，还和用户自身或者项目自身相关。偏置项即考虑用户的严格程度和项目的质量，使得模型能更好地拟合用户真实偏好的参数项，可显著提高推荐性能[27]。表示为公式(12)：

$$R_{ui} = r_{ui} + b_i + b_u \qquad 公式(12)$$

其中，$r_{ui}$为用户 $u$ 对产品 i 的打分，$b_i$ 为产品偏置评分，$b_u$ 为用户偏置得分，$R_{ui}$为修正后用户 $u$ 对产品 i 的偏好。基于此，将用户的长短偏好作为偏置项以表示其综合偏好，如公式(13)：

$$R_{ui} = p_{ui} + p_{ij_G} + p_{ij_p} + p_{ij_B} \qquad 公式(13)$$

### 3.4 基于注意力机制的长短偏好权重调节

注意力机制主要运用在深度学习的各个领域，其核心设计思想源于人类的视觉注意力机制。人类视觉总是快速扫描全局，并马上聚焦于需要重点关注的目标区域，也就是通常所说的注意力焦点，而后对这一区域投入更多注意力资源，以获取更多所需要关注的细节信息，并抑制无用信息。深度学习注意力模型的选择与视觉注意力机制类似，核心目标也是从众多输入特征中选择出对当前输出结果更关键的特征，被广泛使用在自然语言处理、图像识别及语音识别、个性化推荐等各种不同类型的深度学习任务中。在 RNN Encoder-Decoder 模型中，注意力机制可简要表示为以下过程：

$$X = \{x_1, x_2, x_3, \cdots\cdots x_n\} \qquad 公式(14)$$

$$h_t = f(x_t, h_{t-1}) \qquad 公式(15)$$

$$S_j = q(\{h_1, h_2, h_3, \cdots\cdots h_n\}) \qquad 公式(16)$$

$$\propto_{ij} = align(h_i, S_j) \qquad 公式(17)$$

$X$ 表示 Encoder 网络的输入特征向量，$h_t$ 表示 Encoder 网络每个神经元的输出状态，$S_j$ 表示一次前向传播 Encoder 网络的最终输出，当执行 Decoder 过程时，即启动注意力模型通过 align 函数计算 $S_j$ 与每个神经元输出$\{h_1, h_2, \cdots\cdots h_n\}$之间的权重关系$\propto_{ij}$，且$\sum_{i=1}^{n} \propto_{ij} = 1$[29]。基于此思想，通过赋予公式(4)中 $x$ 不同的值，以调整预测目标评分 $R_{ui}$与用户长短偏好之间的关系。

## 4 实验与结果

### 4.1 研究数据与评分计算过程

实验采取两个数据集对本文提出的推荐方法进行验证。一是合作伙伴提供的苏宁易购电商网站的历史数据(Data_1)；另外一个是 Amazon 电商数据集(Data_2：http://snap.stanford.edu/data/amazon/productGraph/categoryFiles/)。对于 Data_1，没有用户评分，需要按照 2.1 中的方法将用户的隐式反馈进行计算作为用户对于每件产品偏好的直接评分，而 Amazon 数据集仅有用户打分，使用此打分作为用户产品的直接评分。经清洗后数据集的统计描述见表 1。

采用章节 2 中的方法计算用户对于每件产品在类别、品牌、价格上的偏好得分。接下来将以 Data_1 中的一位用户行为数据作为示例阐述本研究的用户评分计算过程。此用户的部分行为数据如下：

表 1　实验数据描述

| 数据描述 | Data_1 | Data_2 |
| --- | --- | --- |
| 有无用户显性评分 | 无 | 有 |
| 用户数量 | 608 | 2326 |
| 项目数量 | 3274 | 1404 |
| 评分数量 | 78836 | 93605 |
| 用户最少打分数量 | 10 | 10 |
| 项目最少打分数量 | 10 | 10 |
| 数据稀疏性 | 96.04% | 97.13% |

```
0000066c84079975340f9ed898825551
000000000126823313:1509940376000:BROWSE
|000000000109830038:1509940475000:BROWSE
|000000000109830038:1509940444000:BROWSE
|000000000126507919:1508812552000:CART
|000000000137280398:1508025116000:BROWSE
|000000000143689868:1509670166000:OTHER
|000000000148922124:1509936814000:BUY|……
```

其中 0000066c84079975340f9ed898825551 为用户 ID，每一次行为用“|”分隔，每一次行为的第一列如“000000000126823313”为产品 ID，第二列如“1509940376000”为时间戳，第三列为行为类型，包括 BROWSE、OTHER、CART、COLLECT、BUY 五种行为，此用户共有 247 次行为。

(1) 根据时间戳按倒序排列用户的每一次行为，即最近发生的行为在最前。时间周期的选择与划分有多种方法，并非本研究的重点，为方便计算，这里按照行为次数将每位用户的网络行为等分为 10 个周期。以此用户为例，倒序排列后，按其 1～25、26～50、…、201～225、226～247 次行为进行划分。

(2) 将每一次用户行为按照 2.1 中的描述进行编码，即 BROWSE 为 1，OTHER 为 2，CART 和 COLLECT 为 3，BUY 为 4。

(3) 计算用户对每一件产品的修正评分。以此用户购买的产品 000000000148922124（海尔洗衣机 XQG80-HB14636、类别：大家电洗衣机、品牌：海尔、价格：3 299）为例。此产品的购买行为发生在周期 2 中，且在此周期中用户关注洗衣机 5 次，则根据公式(1)和公式(4)得：

$$p_{ij_C} = x\frac{10+1-2}{10}\left(\alpha\times\frac{12}{24.7}+\beta\times 4\right)=1.228x$$

为了突出产品特征对于用户偏好的影响，这里 $\alpha=0.75$，$\beta=0.25$，然后计算用户的品牌偏好和价格偏好，海尔品牌的产品在每个周期内出现的次数为(7，12，9，11，3，0，0，6，4，0)，3 299 对应的洗衣机价格十分位数为 0.4，如表 2 所示：

表 2　洗衣机价格十分位数

| 价格 | 分位数 |
| --- | --- |
| 249－998 | 0.1 |
| 1 088－1 898 | 0.2 |
| 1 949－2 799 | 0.3 |
| 2 838－3 598 | 0.4 |
| 3 649－4 100 | 0.5 |
| 4 152－5 399 | 0.6 |
| 5 485－7 198 | 0.7 |
| 7 288－9 799 | 0.8 |
| 9 888－15 900 | 0.9 |
| 15 998－33 999 | 1.0 |

价格分位数为 0.4 的洗衣机在每个周期内出现的次数为(4，6，5，6，7，9，3，4，11，7)，则根据公式(5)和公式(6)得：

$$p_{ij_P}=y_1\left(0.055\left(e^{-1}\times\left(\frac{7\times 0.75}{24.7}+1\right)+e^{-2}\times\left(\frac{12\times 0.75}{24.7+1}+\cdots+e^{-9}\times\left(\frac{4\times 0.75}{24.7+1}\right)\right)\right)\right)=0.726y_1$$

$$p_{ij_B}=y_2\left(0.055\left(e^{-1}\times\left(\frac{4\times 0.75}{24.7+2}+e^{-2}\times\left(\frac{6\times 0.75}{24.7+2}+\cdots+e^{-10}\times\left(\frac{7\times 0.75}{24.7+2}\right)\right)\right)\right)\right)=0.664y_2$$

(4) 计算系数 $y_1$，$y_2$。此用户一共关注了 9 种品牌和 7 种价格，出现的频次分别为(43，21，52，9，15，12，17，49，29)和(8，13，35，62，58，53，18)，根据公式(8)、公式(9)、公式(10)和公式(11)得：

$$E_{uB}=-\left(\frac{43}{247}\times\log\frac{43}{247}+\frac{21}{247}\times\log\frac{21}{247}+\cdots+\frac{29}{247}\times\log\frac{29}{247}\right)=-2.036$$

$$E_{uP}=-\left(\frac{8}{247}\times\log\frac{8}{247}+\frac{13}{247}\times\log\frac{13}{247}+\cdots+\frac{53}{247}\times\log\frac{53}{247}\right)=-1.751$$

$$y_1=(1-x)*\frac{-2.036}{-2.036-1.751}=0.538(1-x)$$

$$y_2=(1-x)*\frac{-1.751}{-2.036-1.751}=0.462(1-x)$$

(5) 最后根据公式(13)得到用户对此产品的修正评分：

$$R_{ui}=4+1.228x+0.391(1-x)+0.307(1-x)=4.698+0.53x$$

### 4.2 评价指标

本文采用 Top－N 推荐中准确率（Pre@N）、召回率（Rec@N）以及多样性（Div@N）作为评价指标。准确率表示正确推荐的项目占所有推荐项目的比例，召回率表示正确推荐的项目占实际购买项目比例。一般情况下，准确率和召回率越高，表明推荐算法的性能越好，如公式（18）、公式（19）所示：

$$Pre@N=\frac{|L_t \cap L_r|}{L_r} \quad 公式(18)$$

$$Rec@N=\frac{|L_t \cap L_r\ |}{L_t} \quad 公式(19)$$

其中，$L_t$ 是用户实际浏览的项目集，$L_r$ 是推荐结果集。推荐结果的多样性指其多大程度上满足用户的兴趣，覆盖用户不同的兴趣领域。多样性描述的是推荐列表中物品两两之间的差异性。假设 $S(i,j)$ 描述了物品 $i$ 和物品 $j$ 之间的相似度，那么用户 $u$ 的推荐列表 $R(u)$ 的多样性定义如公式（20）所示：

$$Diversity_u=1-\frac{\sum_{i,j\in R(u),i\neq j)} S(i,j)}{0.5|R(u)|(|R(u)|-1)} \quad 公式(20)$$

推荐系统的整体多样性即所有用户推荐列表的平均值，如公式（21）所示：

$$Diversity_{all}=\frac{1}{|U|}\sum_{u\in U} Diversity(R(u)) \quad 公式(21)$$

### 4.3 结果分析

本实验将采用以下六种推荐算法对本文提出的面向消费者长短偏好调节的可解释个性化推荐方法进行验证：

（1）基于用户的协同过滤 UserCF[34]：根据用户的评分数据寻找目标用户的近邻用户，然后将近邻用户喜欢的项目推荐给目标用户。

（2）基于项目的协同过滤 ItemCF[35]：根据所有用户的历史偏好数据计算物品之间的相似性，然后把与用户喜欢的物品相类似的物品推荐给用户。

（3）SVD 奇异值矩阵分解推荐算法[36]，将 user-item 矩阵分解为两个低维矩阵相乘，实现评分预测，又称为隐语义模型（LFM）。

（4）NMF 非负矩阵分解推荐算法[37]，另一种经典的矩阵分解算法，其改进是分解得到的特征矩阵元素都要大于 0。

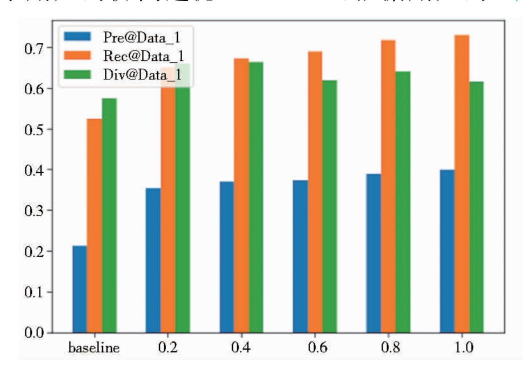
（5）基于卷积神经网络的推荐算法[38]：将用户与项目属性编码，然后 embedding 作为卷积神经网络的特征输入，对用户评分进行预测，形成推荐。

（6）基于 LSTM 长短记忆网络的推荐算法[39]：将长短记忆（LSTM）递归神经网络应用于用户偏好预测，其推荐结果不仅基于用户的历史行为，同时也根据用户行为的时间顺序进行预测。

基于以上推荐算法，采用 K＝10 折交叉验证（HoudOut Cross Validation）的方法，取推荐项目数量 N＝（5，10，20），计算不同长短偏好权重 $x$＝（0.1，0.2，0.3，0.4，0.5，0.6，0.7，0.8，0.9，1.0）取值时推荐结果的准确率、召回率和多样性进行比较与验证。

#### 4.3.1 本方法在不同数据集上的整体表现

在两个数据集上，使用所有的推荐算法和不同推荐列表数量（Top-N）时，各评价指标的整体平均表现见图 1。其中横轴表示长短偏好权重 x 的取值，纵轴为各指标结果的平均值，左边为 Data_1 的结果，右边为 Data_2 的结果。



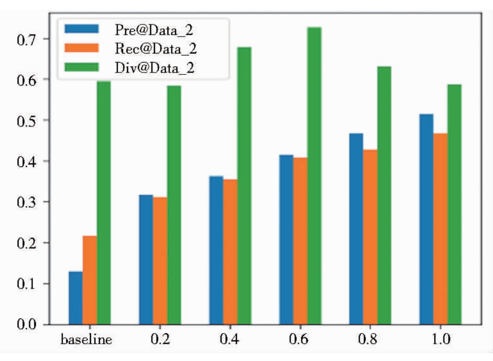



图 1 不同数据集上推荐结果评价指标比较

整体上而言，在两个数据集上，加入不同权重的长短偏好评分后，推荐结果的平均准确率、召回率和多样性指标上都有明显的提升。对于 Data_1，随着 x 取值的增大，推荐结果的准确率和召回率提升缓慢，而多样性在 x＝0.4 左右达到最大；对于 Data_2，随着 x 取值的增大，推荐结果的准确率和召回率显著提升，而多样

性在 x = 0.6 左右达到最大值。

### 4.3.2 本方法在不同推荐项目个数上(Top-N)的整体表现

选用 Data_1,比较不同的推荐项目个数(Top-N),x 取不同值时所有推荐算法的平均表现。根据准确率的定义,一般情况而言,对于同一推荐算法,N 取值越大,其推荐结果的准确率越低,见图 2,N = 5 时,准确率最高,N = 20 时,准确率最低。然而当 $0.2 < x < 0.7$ 时,$Pre@N = 10 > Pre@N = 5$,也说明了本方法提高了推荐结果的准确率。对于召回率指标,N 的取值越大,推荐结果的召回率也越高,且随着 x 的增大,召回率呈现上升趋势。对于多样性指标,当 N = 5 时,推荐结果的多样性随着 x 的增加持续上升,当 N = (10,20)时,推荐结果的多样性在 $x \in (0.4 - 0.8)$之间有最大值。一方面说明当 N 取值较小时,本文提出的推荐方法提升了推荐结果的准确率与命中率,因而同时提升了其多样性,当 N 取值较大时,推荐结果的多样性会随着准确率的提升而降低。

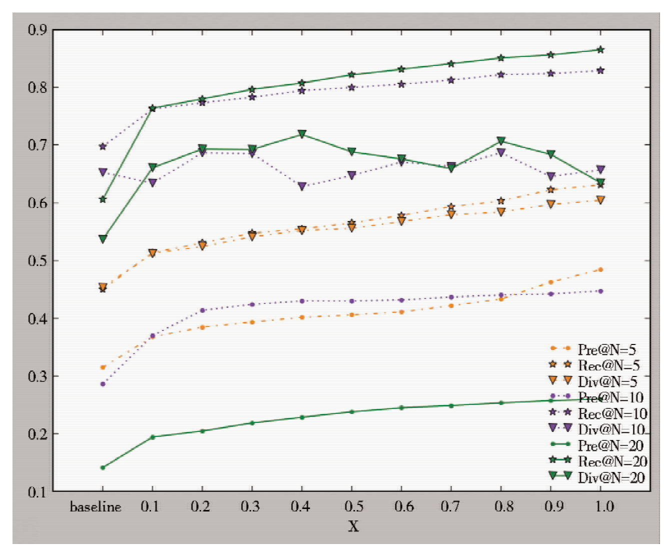



图 2　不同推荐项目个数的推荐结果评价指标比较

### 4.3.3 本方法在不同推荐算法中的具体表现分析

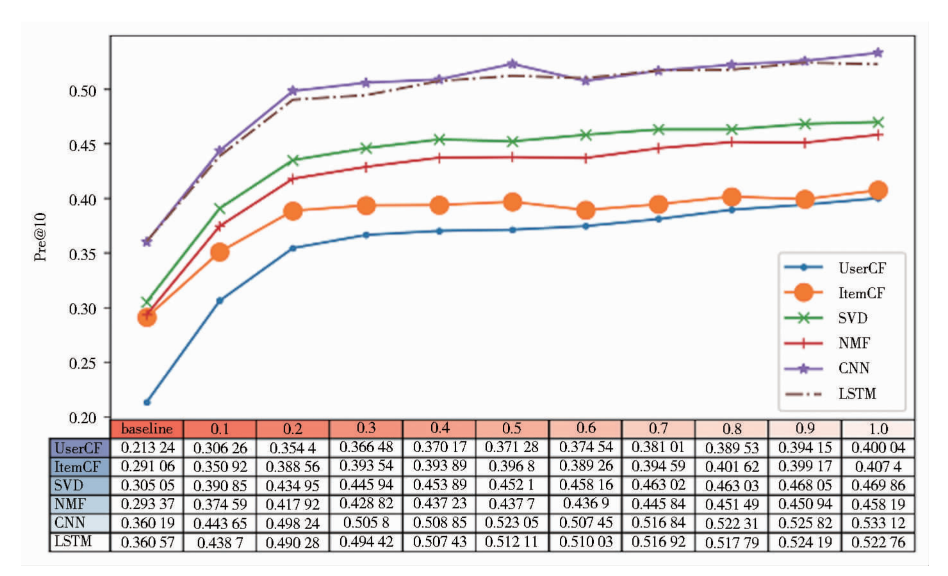
选择 Data_1,N = 10,比较 x 取不同值时各种推荐算法的表现,见图 3、图 4、图 5,横坐标表示消费者短期偏好 x 的取值,纵坐标分别表示准确率、召回率和多样性。从图 3 和图 4 中可以看出,对于所有的基线推荐算法,在使用本文提出的方法对消费者偏好进行再计算后,在推荐性能上都有较大的提升,说明了本文提出推荐方法的有效性。在推荐的准确率和召回率上,UserCF 算法的性能最低,其次是 ItemCF,应该是在数据较为稀疏的情况下,基于协同过滤推荐算法的整体性能较低。性能相对最好的是基于卷积神经网络(CNN)的推荐和基于 LSTM 的推荐算法,可能是因为这两种推荐算法将项目的特征和用户行为时间序列信息作为输入,而本文提出的方法,在用户偏好得分中加入了用户的长短特征偏好得分,两相结合更能准确表现出用户的偏好;也可能仅仅是因为深度学习算法更加优秀的特征提取与表征能力,以及其深层次、线性与非线性相结合的模型结构,在预测任务上更加优异的性能所导致。

整体上而言,长短偏好评分的引入,所有推荐算法的准确率和召回率都明显提升;而随着 x 取值的增大,算法的准确率和召回率变化趋于平稳。而对于推荐结果的多样性变化较为显著,各种推荐算法的多样性多在 $x \in (0.6 - 08)$之间达到最大值。

以上结果说明本研究提出的面向用户长短期偏好调节的可解释个性化推荐算法在不同的数据集、不同的推荐数量(Top-N)和不同的推荐算法上,以及针对不同的用户偏好计算方法(显式反馈或隐式反馈)都有不错的表现,能显著提升推荐性能。在无需对各种推荐算法模型进行较大改变的情况下,提升了推荐结果的准确率与召回率。另外可对长短偏好权重系数进行改变,从而调整推荐结果的准确率和多样性,且可根据权重系数较高的偏好特征对推荐列表形成相应的推荐解释。

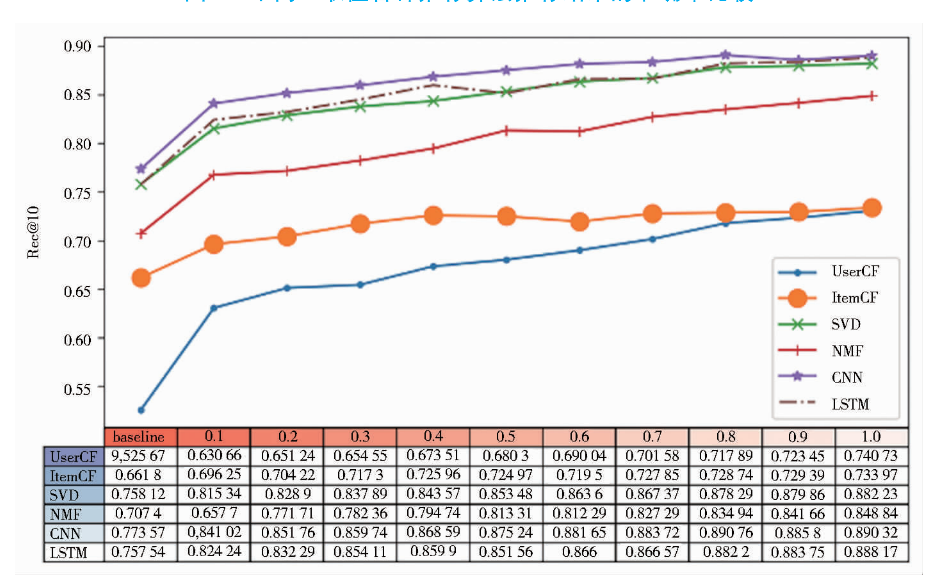
## 5 总结与展望

本文基于网络生活方式理论,将产品类别信息作为用户的短期偏好,产品感知价格和品牌信息作为用



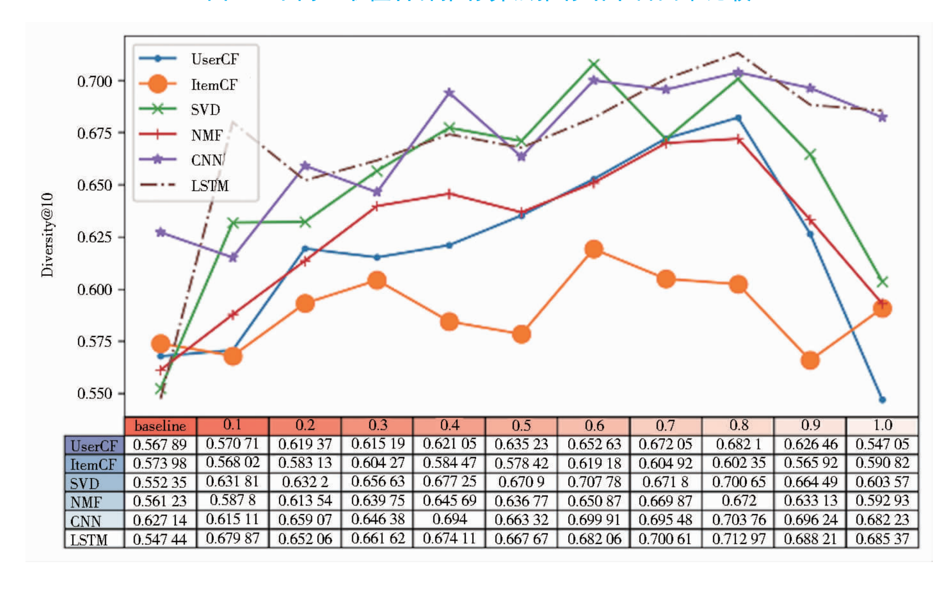

| | baseline | 0.1 | 0.2 | 0.3 | 0.4 | 0.5 | 0.6 | 0.7 | 0.8 | 0.9 | 1.0 |
|---|---|---|---|---|---|---|---|---|---|---|---|
| UserCF | 0.213 24 | 0.306 26 | 0.354 4 | 0.366 48 | 0.370 17 | 0.371 28 | 0.374 54 | 0.381 01 | 0.389 53 | 0.394 15 | 0.400 04 |
| ItemCF | 0.291 06 | 0.350 92 | 0.388 56 | 0.393 54 | 0.393 89 | 0.396 8 | 0.389 26 | 0.394 59 | 0.401 62 | 0.399 17 | 0.407 4 |
| SVD | 0.305 05 | 0.390 85 | 0.434 95 | 0.445 94 | 0.453 89 | 0.452 1 | 0.458 16 | 0.463 02 | 0.463 03 | 0.468 05 | 0.469 86 |
| NMF | 0.293 37 | 0.374 59 | 0.417 92 | 0.428 82 | 0.437 23 | 0.437 7 | 0.436 9 | 0.445 84 | 0.451 49 | 0.450 94 | 0.458 19 |
| CNN | 0.360 19 | 0.443 65 | 0.498 24 | 0.505 8 | 0.508 85 | 0.523 05 | 0.507 45 | 0.516 84 | 0.522 31 | 0.525 82 | 0.533 12 |
| LSTM | 0.360 57 | 0.438 7 | 0.490 28 | 0.494 42 | 0.507 43 | 0.512 11 | 0.510 03 | 0.516 92 | 0.517 79 | 0.524 19 | 0.522 76 |

图 3　不同 $x$ 取值各种推荐算法推荐结果的准确率比较




| | baseline | 0.1 | 0.2 | 0.3 | 0.4 | 0.5 | 0.6 | 0.7 | 0.8 | 0.9 | 1.0 |
|---|---|---|---|---|---|---|---|---|---|---|---|
| UserCF | 9,525 67 | 0.630 66 | 0.651 24 | 0.654 55 | 0.673 51 | 0.680 3 | 0.690 04 | 0.701 58 | 0.717 89 | 0.723 45 | 0.740 73 |
| ItemCF | 0.661 8 | 0.696 25 | 0.704 22 | 0.717 3 | 0.725 96 | 0.724 97 | 0.719 5 | 0.727 85 | 0.728 74 | 0.729 39 | 0.733 97 |
| SVD | 0.758 12 | 0.815 34 | 0.828 9 | 0.837 89 | 0.843 57 | 0.853 48 | 0.863 6 | 0.867 37 | 0.878 29 | 0.879 86 | 0.882 23 |
| NMF | 0.707 4 | 0.657 7 | 0.771 71 | 0.782 36 | 0.794 74 | 0.813 31 | 0.812 29 | 0.827 29 | 0.834 94 | 0.841 66 | 0.848 84 |
| CNN | 0.773 57 | 0,841 02 | 0.851 76 | 0.859 74 | 0.868 59 | 0.875 24 | 0.881 65 | 0.883 72 | 0.890 76 | 0.885 8 | 0.890 32 |
| LSTM | 0.757 54 | 0.824 24 | 0.832 29 | 0.854 11 | 0.859 9 | 0.851 56 | 0.866 | 0.866 57 | 0.882 2 | 0.883 75 | 0.888 17 |

图 4　不同 $x$ 取值各种推荐算法推荐结果召回率比较




| | baseline | 0.1 | 0.2 | 0.3 | 0.4 | 0.5 | 0.6 | 0.7 | 0.8 | 0.9 | 1.0 |
|---|---|---|---|---|---|---|---|---|---|---|---|
| UserCF | 0.567 89 | 0.570 71 | 0.619 37 | 0.615 19 | 0.621 05 | 0.635 23 | 0.652 63 | 0.672 05 | 0.682 1 | 0.626 46 | 0.547 05 |
| ItemCF | 0.573 98 | 0.568 02 | 0.583 13 | 0.604 27 | 0.584 47 | 0.578 42 | 0.619 18 | 0.604 92 | 0.602 35 | 0.565 92 | 0.590 82 |
| SVD | 0.552 35 | 0.631 81 | 0.632 2 | 0.656 63 | 0.677 25 | 0.670 9 | 0.707 78 | 0.671 8 | 0.700 65 | 0.664 49 | 0.603 57 |
| NMF | 0.561 23 | 0.587 8 | 0.613 54 | 0.639 75 | 0.645 69 | 0.636 77 | 0.650 87 | 0.669 87 | 0.672 | 0.633 13 | 0.592 93 |
| CNN | 0.627 14 | 0.615 11 | 0.659 07 | 0.646 38 | 0.694 | 0.663 32 | 0.699 91 | 0.695 48 | 0.703 76 | 0.696 24 | 0.682 23 |
| LSTM | 0.547 44 | 0.679 87 | 0.652 06 | 0.661 62 | 0.674 11 | 0.667 67 | 0.682 06 | 0.700 61 | 0.712 97 | 0.688 21 | 0.685 37 |

图 5　不同 $x$ 取值各种推荐算法推荐结果多样性比较

户的长期偏好;借鉴用户评分偏置及注意力机制的思想,将用户长短期偏好及其直接评分相结合构建 User-Item 偏好矩阵,调整长短期偏好权重系数以形成面向不同用户长短偏好的可解释推荐列表,取得了良好的推荐效果。本研究具有以下创新与价值:

(1)无需对原有的推荐模型进行较大的更改,仅需新的用户长短偏好计算模块,即可显著提升各种推荐模型的性能。避免了对原有推荐模型复杂度的提升,有利于产业界的快速应用。

(2)推荐结果准确率和多样性的可调节。整体上而言,当短期偏好系数 $x<0.6$ 时,x 增大时,推荐结果的准确率、召回率和多样性都显著提升;当 $x\geq0.6$ 时,推荐结果的多样性降低,准确率变化不显著。因而,本文提出的推荐算法可基于用户长短偏好权重系数的改变,对推荐结果的准确率和多样性进行调整,为“过度特化”问题的解决提供了思路。

(3)推荐结果的可解释性。推荐算法的可解释性体现在依据该算法逻辑产生的推荐结果具有明确合理的推荐理由[2]。一般来说,在基于知识的推荐算法中,解释一般基于编码的规则,而基于协同过滤的推荐算法中,解释一般基于用户偏好的获取方式[25]。因而,对于 UserCF,根据不同用户对相同产品的评分计算用户之间的关系,在具有相似偏好的用户之间进行推荐,故其解释性表现为“喜欢产品 X 的用户也喜欢 Y”;对于 ItemCF 算法,通过计算不同用户对不同产品的评分获得产品之间的关系,对目标用户进行相似物品的推荐,故其解释性表现为“因为您喜欢产品 X,可能也喜欢产品 Y”;而对于本文所提出的方法,将用户的长短偏好作为评分偏置加入到用户的直接评分中,当短期偏好权重系数较大时,算法更注重产品的类别信息,其推荐结果的解释性表现为“您近期较为关注此类产品,可能会喜欢产品 X”;当长期偏好权重系数较大时,其推荐结果的解释性表现为“根据您的生活方式(品牌或价格偏好)向您推荐了产品 X”。因而,而本文提出的推荐算法从用户近期产品需求和长期生活方式偏好给出推荐结果的理由,其推荐理由的合理性与丰富性都更高。另外相较于深度学习推荐算法,虽也可结合用户特征及其行为时间序列信息,基于注意力机制,可知晓其推荐结果和哪些因素更加相关。但注意力模型庞大的计算量,难以实现实时推荐。

(4)本研究根据一定规则改变预测任务中的目标值,即用户评分的改变,研究产品特征对于用户偏好的影响,为特征工程的研究提供了新的思路与方法。

由于篇幅的关系,本文仅介绍了如何借鉴评分偏置与注意力模型的思想,将用户长短期偏好结合用户的直接评分,应用于各种推荐算法。而对于如何将用户长短偏好特征作为推荐模型的直接输入,并基于各种推荐算法的特点,构建新的可解释推荐模型,将在接下来的工作中展开。另外,如何根据用户长短期偏好和不同的推荐结果,生成个性化的解释;以及权重参数的个性化、自适应调节机制将是未来的研究重点。

**参考文献:**

[1] LIU P, ZHANG L, GULLA J, et al. Dynamic attention-based explainable recommendation with textual and visual fusion[J]. Information processing & management, 2019, 57(6): 102099.

[2] NAJI H. Improving recommendation system based on homophily principle and demographic[J]. Research journal of applied sciences, 2016, 11(10): 1102－1106.

[3] ZHAO X, GUO Y, HE Y, et al. We know what you want to buy: a demographic-based system for product recommendation on microblogs[C]// ACM. KDD '14: proceedings of the 20th ACM SIGKDD international conference on knowledge discovery and data mining. New York: ACM press, 2014: 1935－1944.

[4] HUANG Y, LIU H, LI W, et al. Lifestyles in amazon: evidence from online reviews enhanced recommender system[J]. International journal of market research, 2020, 62(6): 689－706.

[5] 侯银秀, 李伟卿, 王伟军, 等. 基于用户偏好与商品属性情感匹配的图书个性化推荐研究[J]. 数据分析与知识发现, 2017, 1(8): 9－17.

[6] BI J, LIU Y, FAN Z, et al. A deep neural networks based recommendation algorithm using user and item basic data[J]. International journal of machine learning and cybernetics, 2020, 11(4): 763－777.

[7] 梁昌勇, 范汝鑫, 陆文星, 等. 基于 CNN-LFM 模型的个性化推荐[J]. 计算机仿真, 2020, 37(3): 399－404.

[8] BEENEN G, LING K, WANG X, et al. Using social psychology to motivate contributions to online communities[C]// ACM. Proceedings of the 2004 ACM conference on computer supported cooperative work. New York: ACM press, 2004: 212－221.

[9] BENNETT P. Modeling the impact of short-term and long-term behavior on search personalization[C]// ACM. International ACM SIGIR conference on research & development in information retrieval. New York: ACM, 2012: 185－194.

[10] CHU Y, LEE J. The experiential preferences of the online consumers in different internet shopping lifestyles towards online shopping websites [C]// Springer. International Conference on Human-Computer Interaction. Lisbon: Springer, 2007.

[11] DIAZ A, GOMEZ M, MOLINA A, et al. A segmentation study of

cinema consumers based on values and lifestyle[J]. Journal of retailing and consumer services, 2018, 3(41): 79 – 89.
[12] SARKI I, BHUTTO N, ARSHAD I, et al. Impact of Pakistani university student's cultural values and lifestyles on meaning of brands [J]. Interdisciplinary journal of contemporary research in business, 2012, 3(9): 643 – 654.
[13] SWINYARD W R. Shopping mall customer values: the national mall shopper and the list of values[J]. Journal of retailing and consumer services, 1998, 5(3):167 – 172.
[14] 潘煜, 高丽, 王方华. 生活方式、顾客感知价值对中国消费者购买行为影响[J]. 系统管理学报, 2009, 18(6): 601 – 607.
[15] 潘煜, 罗莉娟, 刘丹, 等. 基于网络生活方式的个人用户云服务购买意愿研究[J]. 系统管理学报, 2013, 22(4): 477 – 486.
[16] XIONG L, CHEN X, HUANG T, et al. Temporal collaborative filtering with Bayesian probabilistic tensor factorization[C]// SDM. Proceedings of the SIAM international conference on data mining. Philadelphia: SIAM, 2010: 211 – 222.
[17] 张婷婷, 王伟军, 黄英辉, 等. 基于屏幕视觉热区的中文短文本关键词实时提取方法[J]. 情报学报, 2016, 35 (12): 1178 – 1188.
[18] 刘凯. 基于屏幕视觉热区的用户偏好提取及个性化推荐[M]. 北京:科学出版社, 2016.
[19] HU L, LI C, SHI C, et al. Graph neural news recommendation with long-term and short-term interest modeling[J]. Information processing and management, 2020, 57(2):1 – 10.
[20] CHEN D, ZHANG R, YUAN B, et al. Sequence-aware recommendation with long-term and short-term attention memory networks [C]// IEEE. 2019 20th IEEE international conference on mobile data management. IEEE, 2019: 437 – 442.
[21] XIANG L, YUAN Q, ZHAO S, et al. Temporal recommendation on graphs via long- and short-term preference fusion[C]// ACM. KDD '10: proceedings of the 16th ACM SIGKDD international conference on knowledge discovery and data mining. New York: ACM press, 2010: 723 – 732.
[22] 王微微, 夏秀峰, 李晓明. 一种基于用户行为反馈的兴趣度模型更新算法[J]. 辽宁大学学报(自然科学版), 2011, 38 (1): 40 – 45.
[23] GEDIKLI F, JANNACH D, GE M, et al. How should I explain? A comparison of different explanation types for recommender systems [J]. International journal of human-computer studies, 2014, 72 (4): 367 – 382.
[24] TINTAREV N, MASTHOFF J. Designing and evaluating explanations for recommender systems[M]. Boston: Recommender Systems Hand - book, Springer, 2011: 479 – 510.
[25] ZHANG Y, CHEN X. Explainable recommendation: a survey and new perspectives[J]. ArXiv: information retrieval, 2018, 14(1): 1 – 101.
[26] 余以胜, 韦锐, 刘鑫艳. 可解释的实时图书信息推荐模型研究[J]. 情报学报, 2019, 38(2): 209 – 216.
[27] ZHANG Y, LAI G, ZHANG M, et al. Explicit factor models for explainable recommendation based on phrase-level sentiment analysis[C]// ACM. International ACM SIGIR conference on research and development in information retrieval. New York: ACM press, 2014: 83 – 92.
[28] BAHDANAU D, CHO K, BENGIO Y. Neural machine translation by jointly learning to align and translate[EB/OL]. [2021 – 04 – 01]. https://www.researchgate.net/publication/265252627_Neural_Machine_Translation_by_Jointly_Learning_to_Align_and_Translate.
[29] HU L, JIAN S, CAO L, et al. Interpretable recommendation via attraction modeling: learning multilevel attractiveness over multimodal movie contents[C]// AAAI. Twenty-seventh international joint conference on artificial intelligence IJCAI-18. Stockholm: AAAI Press, 2018, 7: 3400 – 3406
[30] SEO S, HUANG J, YANG H, et al. Interpretable convolutional neural networks with dual local and global attention for review rating prediction[C]// ACM. RecSys '17: proceedings of the eleventh ACM conference on recommender systems. New York: ACM press, 2017, 8: 297 – 305.
[31] YU J, ZHU H, CHANG C, et al. Influence function for unbiased recommendation[C]// ACM. SIGIR '20: the 43rd international ACM SIGIR conference on research and development in information retrieval. New York: ACM press, 2020, 7: 1929 – 1932.
[32] 崔春生. 电子商务隐式浏览输入中的用户聚类分析[J]. 图书情报工作, 2011, 55(14): 130 – 134.
[33] 王军, 张子柯. 基于社会化标签信息熵的个性化推荐算法[J]. 图书情报工作, 2013, 57(23): 31 – 35.
[34] LIU H, HU Z, MIAN A, et al. A new user similarity model to improve the accuracy of collaborative filtering[J]. Knowledge-based systems, 2014, 56(1):156 – 166.
[35] DESHPANDE M, KARYPIS G. Item-based top-N recommendation algorithms[J]. ACM transactions on information systems, 2004, 22(1):143 – 177.
[36] POLAT H, DU W. SVD-based collaborative filtering with privacy [C]// ACM. SAC '05: proceedings of the 2005 ACM symposium on applied computing. New York: ACM press, 2005, 3: 791 – 795.
[37] WU Y, LI Y, QIAN R. NE-UserCF: collaborative filtering recommender system model based on NMF and E2LSH[J]. International journal of performability engineering, 2017, 13(5):610 – 619.
[38] BI J W, LIU Y, FAN Z P. A deep neural networks based recommendation algorithm using user and item basic data[J]. International journal of machine learning and cybernetics, 2020, 11(4): 763 – 777.
[39] DEVOOGHT R, BERSINI H. Long and short-term recommendations with recurrent neural networks[C]// ACM. UMAP '17: proceedings of the 25th conference on user modeling, adaptation

and personalization. New York: ACM press, 2017, 7: 13－21.

**作者贡献说明:**

李伟卿:负责数据处理,论文撰写;

池毛毛:负责论文修改;

王伟军:负责论文创意、框架提出及文章修改。

## Explainable Personalized Recommendation Method Based on Adjustment of Users' Long- and Short-Term Preferences

Li Weiqing[1,2] Chi Maomao[1] Wang Weijun[2]

[1] School of Information Management, Central China Normal University, Wuhan 430079

[2] Key Laboratory of Adolescent Cyber Psychology and Behavior, Ministry of Education, Wuhan 430079

Abstract: [Purpose/significance] We put forward an explainable personalized recommendation method based on adjustment of users' long- and short-preferences in view of the current problems that increasingly complexity and more feature data inputs of recommendation models, low interpretability of traditional recommendation models and over-specialization of recommendation results. [Method/process] We constructed a user preference model from two dimensions of users' recent product needs and their long-term lifestyles, used the user's rating bias and attention mechanism for reference, combined the user's long- and short-term preference with their direct score to predict the score of unknown items, and formed the Top-N recommendations. [Result/conclusion] The experimental results on two datasets showed that our method had a good performance to different user behaviors (explicit feedback or implicit feedback), different number of Top-N recommended items, and in different recommendation algorithms. It improves the accuracy, recall and diversity of the recommendation results without making great changes to various recommendation models, and based on the change of long- and short-term preference coefficients, it realizes the adjustment to the diversity and accuracy of the recommendation results, and form the corresponding recommended explanation.

Keywords: personalized recommendation user preference explainable recommendation adjustment of long- and short-preference